

KLASIFIKASI POSTUR DUDUK BERBASIS CONVOLUTIONAL NEURAL NETWORK (CNN) UNTUK EVALUASI RESIKO ERGONOMI

Ahmad Sanusi^{1*}, Dede Brahma Arianto²

^{1,2}Informatika, Fakultas Sains dan Teknik, Universitas Faletahan, I. Palamunan No.72, Palamunan, Kecamatan Kramatwatu, Kabupaten Serang, Serang, Banten Telp : (0254) 42161.

Keywords:

Postur Duduk;
Deep Learning;
MobileNetV2;
Transfer Learning;
Klasifikasi Citra.

Correspondent Email:

sanusiahmdad@gmail.com

Abstrak. Postur duduk yang tidak ergonomis merupakan salah satu penyebab utama gangguan muskuloskeletal yang banyak dialami oleh pekerja dan pelajar. Deteksi postur duduk secara otomatis menggunakan kecerdasan buatan berpotensi menjadi solusi pemantauan yang efektif dan efisien. Penelitian ini mengembangkan sistem klasifikasi postur duduk berbasis *deep learning* menggunakan arsitektur MobileNetV2 dengan pendekatan *transfer learning*. Dataset yang digunakan terdiri dari 938 citra tiga kelas postur duduk, yaitu *good_posture*, *forward_lean*, dan *backward_lean*, yang diperoleh dari platform Roboflow Universe. Pelatihan dilakukan dalam dua fase menggunakan strategi *progressive fine-tuning* dengan berbagai mekanisme optimasi seperti *EarlyStopping*, *ModelCheckpoint*, dan *ReduceLROnPlateau*. Hasil eksperimen menunjukkan bahwa model mencapai akurasi validasi terbaik sebesar 97,33% dan akurasi pada data uji sebesar 95,74% dengan *macro F1-score* 0,9565. Model yang dihasilkan memiliki ukuran yang ringan dan telah dikonversi ke format TFLite sehingga siap diimplementasikan pada perangkat mobile. Penelitian ini membuktikan bahwa *transfer learning* berbasis MobileNetV2 mampu mengklasifikasikan postur duduk secara akurat meskipun dengan jumlah data yang terbatas, dan berpotensi dikembangkan lebih lanjut sebagai sistem pemantauan ergonomi secara *real-time*.



Copyright © JITET (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. Improper sitting posture is one of the leading causes of musculoskeletal disorders among workers and students. Automatic sitting posture detection using artificial intelligence has the potential to serve as an effective and efficient monitoring solution. This study develops a sitting posture classification system based on deep learning using the MobileNetV2 architecture with a transfer learning approach. The dataset consists of 938 images across three posture classes, namely *good_posture*, *forward_lean*, and *backward_lean*, obtained from the Roboflow Universe platform. Training was conducted in two phases using a progressive fine-tuning strategy with optimization mechanisms including *EarlyStopping*, *ModelCheckpoint*, and *ReduceLROnPlateau*. Experimental results show that the model achieved a best validation accuracy of 97.33% and a test accuracy of 95.74% with a *macro F1-score* of 0.9565. The resulting model is lightweight and has been converted to TFLite format, making it ready for deployment on mobile devices. This study demonstrates that MobileNetV2-based transfer learning can accurately classify sitting postures even with a limited dataset, and has strong potential for further development as a real-time ergonomic monitoring system.

1. PENDAHULUAN

Aktivitas duduk merupakan salah satu posisi tubuh yang paling banyak dilakukan oleh manusia dalam kehidupan sehari-hari, baik dalam konteks pekerjaan, pendidikan, maupun aktivitas lainnya. Namun di balik kebiasaan tersebut, terdapat risiko kesehatan yang serius apabila tidak diperhatikan dengan baik. Menurut World Health Organization (WHO), sekitar tiga dari empat kecelakaan kerja berkaitan dengan masalah kesehatan yang disebabkan oleh gangguan muskuloskeletal [1]. Gangguan muskuloskeletal sendiri merupakan salah satu permasalahan kesehatan global yang paling serius, di mana berdasarkan data WHO sekitar 1,71 miliar penduduk dunia hidup dengan kondisi ini, menjadikannya sebagai kontributor terbesar terhadap angka disabilitas global [2]. Kondisi ini tidak hanya berdampak pada keterbatasan fisik, tetapi juga menyebabkan penurunan produktivitas kerja, gangguan kesejahteraan, serta menurunnya kemampuan individu untuk berpartisipasi dalam kehidupan sosial. Dampak yang ditimbulkan pun tidak hanya dirasakan oleh individu, melainkan juga memberikan beban ekonomi yang signifikan bagi masyarakat secara luas, baik melalui biaya layanan kesehatan langsung maupun kerugian akibat absensi dan penurunan produktivitas [3]. Kondisi ini menegaskan bahwa gangguan muskuloskeletal bukan sekadar masalah kesehatan individu, melainkan telah menjadi tantangan kesehatan masyarakat yang membutuhkan perhatian dan penanganan secara sistematis.

Salah satu faktor utama yang berkontribusi terhadap meningkatnya risiko gangguan muskuloskeletal adalah kebiasaan duduk dengan postur yang tidak ergonomis. Postur duduk terbagi menjadi dua jenis, yaitu postur duduk ergonomis dan non-ergonomis, di mana postur duduk ergonomis ditandai dengan posisi punggung tegak membentuk lengkung S yang natural sehingga dapat mengurangi nyeri pada leher, punggung, dan lutut, sedangkan postur duduk non-ergonomis ditandai dengan punggung membentuk posisi C atau membungkuk yang memberikan tekanan berlebih pada tulang belakang [1]. Posisi duduk yang tidak sesuai prinsip ergonomi dalam jangka waktu yang lama dapat menyebabkan peningkatan beban pada vertebra lumbal

sehingga menimbulkan keluhan nyeri pada bagian punggung bawah [4]. Hal ini dibuktikan oleh penelitian pada pengrajin karawo yang menunjukkan bahwa responden dengan posisi duduk tidak ergonomis seluruhnya mengalami nyeri punggung bawah kategori sedang hingga berat, sementara mereka yang duduk secara ergonomis hanya mengalami nyeri ringan [4]. Kondisi ini semakin diperparah apabila postur duduk yang tidak benar dilakukan secara berulang dan dalam durasi yang panjang tanpa adanya perubahan posisi, yang pada akhirnya menyebabkan kerusakan pada tendon, ligamen, dan sendi secara perlahan [1].

Berbagai upaya telah dilakukan untuk mendeteksi dan memantau postur duduk secara otomatis sebagai bentuk pencegahan gangguan muskuloskeletal. Salah satunya adalah pengembangan sistem wearable berbasis sensor MPU6050 dengan metode Support Vector Machine (SVM) yang mampu mengklasifikasikan postur duduk menjadi tiga kelas yaitu tegak, membungkuk, dan miring dengan akurasi sistem sebesar 91,6% [5]. Selain itu, dikembangkan pula sistem monitoring postur duduk berbasis sensor load cell dan ultrasonik menggunakan algoritma K-Nearest Neighbor (KNN) yang menghasilkan akurasi klasifikasi tertinggi sebesar 90% [6]. Meskipun demikian, sistem-sistem tersebut masih memiliki keterbatasan yang cukup signifikan. Sistem wearable mengharuskan pengguna mengenakan perangkat tambahan pada tubuh sehingga berpotensi mengganggu kenyamanan aktivitas sehari-hari, sedangkan sistem berbasis sensor memerlukan kalibrasi dan pengukuran ulang secara manual setiap kali terdapat subjek yang berbeda [6]. Keterbatasan-keterbatasan ini menunjukkan perlunya pendekatan yang lebih praktis, non-invasif, dan mampu mengenali pola visual postur duduk secara otomatis tanpa memerlukan perangkat tambahan yang melekat pada tubuh pengguna.

Perkembangan pesat di bidang kecerdasan buatan, khususnya deep learning, membuka peluang baru dalam mengatasi keterbatasan sistem deteksi postur duduk yang ada saat ini. Salah satu arsitektur deep learning yang paling unggul dalam tugas klasifikasi berbasis citra adalah Convolutional Neural Network (CNN). CNN merupakan algoritma deep learning yang dirancang khusus untuk memproses data gambar dengan cara mengekstraksi fitur secara

hierarkis melalui lapisan konvolusi, pooling, dan fully connected, sehingga mampu mengenali pola visual secara otomatis tanpa memerlukan ekstraksi fitur secara manual [7]. Kemampuan CNN dalam klasifikasi gambar telah terbukti menghasilkan performa yang tinggi, di mana pada pengujian menggunakan dataset CIFAR-10 CNN berhasil mencapai akurasi sebesar 93,47% [8], bahkan pada tugas klasifikasi yang lebih spesifik seperti klasifikasi varietas hazelnut, CNN mampu menghasilkan akurasi hingga 98,63% [9]. Keunggulan CNN dibandingkan metode lain seperti SVM dan KNN terletak pada kemampuannya belajar langsung dari data gambar mentah tanpa bergantung pada sensor tambahan yang melekat pada tubuh, sehingga lebih praktis dan non-invasif untuk diterapkan dalam sistem klasifikasi postur duduk. Berdasarkan hal tersebut, penelitian ini mengusulkan pengembangan sistem klasifikasi postur duduk berbasis CNN sebagai upaya pencegahan cedera muskuloskeletal yang lebih otomatis, akurat, dan mudah digunakan.

Beberapa Penelitian terdahulu telah membahas mengenai postur duduk diantaranya ada pada penelitian [5] menggunakan algoritma Support Vector Machine (SVM) berbasis sistem wearable dengan sensor MPU6050 yang berjudul "Pengembangan Sistem Wearable untuk Deteksi Postur Duduk Miring Berbasis Data Sensor MPU6050 dan Metode Support Vector Machine" dengan hasil akurasi 91,6%. Pada penelitian [6] menggunakan algoritma K-Nearest Neighbor (KNN) berbasis sensor load cell dan ultrasonik yang berjudul "Sistem Monitoring Postur Duduk pada Pemain Game Online menggunakan Sensor Load Cell dan Ultrasonik dengan Metode K-Nearest Neighbor (KNN) berbasis Arduino" dengan hasil akurasi 90%. Pada penelitian [10] menggunakan algoritma Random Forest, KNN, SVM, dan Multi-Layer Perceptron (MLP) yang berjudul "Perbandingan Random Forest, K-Nearest Neighbor, Support Vector Machine, dan Multi-Layer Perceptron untuk Deteksi Postur Duduk Berdasarkan Ekstraksi Pose MediaPipe" dengan hasil akurasi terbaik 87,63% menggunakan Random Forest. Pada penelitian [11] menggunakan algoritma CNN dan Long Short-Term Memory (LSTM) yang berjudul "Analisis Performa Metode CNN Dan LSTM Untuk Deteksi Gerakan Angkat Beban" dengan

hasil akurasi 80%. Pada penelitian [12] menggunakan algoritma CNN dengan arsitektur VGG19 dan ResNet-50 yang berjudul "Klasifikasi Pose Yoga Surya Namaskar Menggunakan Algoritma Convolutional Neural Network dengan Arsitektur VGG19 dan ResNet-50" dengan hasil akurasi terbaik 85% menggunakan ResNet-50.

Berdasarkan penelitian-penelitian terdahulu, sebagian besar sistem deteksi postur duduk masih mengandalkan perangkat keras tambahan seperti sensor wearable dan sensor fisik yang memerlukan kalibrasi khusus serta kurang praktis digunakan dalam kehidupan sehari-hari. Sementara penelitian berbasis citra yang ada umumnya menggunakan metode machine learning konvensional seperti Random Forest, KNN, dan SVM yang bergantung pada ekstraksi fitur secara manual, sehingga belum memanfaatkan kemampuan deep learning dalam mengekstraksi fitur visual secara otomatis dan hierarkis dari gambar postur duduk. Selain itu, penelitian yang menggunakan CNN untuk klasifikasi postur tubuh masih berfokus pada gerakan olahraga seperti angkat beban dan yoga, bukan secara spesifik pada postur duduk dari sudut pandang samping (side view). Oleh karena itu, penelitian ini mengusulkan sistem klasifikasi postur duduk menggunakan Convolutional Neural Network (CNN) dengan arsitektur MobileNetV2 berbasis data gambar side view yang terdiri dari tiga kelas yaitu good posture, forward lean, dan backward lean, sebagai upaya pencegahan cedera muskuloskeletal yang lebih praktis, otomatis, dan tidak memerlukan perangkat tambahan pada tubuh pengguna.

2. TINJAUAN PUSTAKA

2.1. Postur Duduk

Postur duduk merupakan posisi tubuh yang terbentuk ketika seseorang berada dalam kondisi duduk, yang secara umum dibedakan menjadi dua kategori yaitu postur ergonomis dan non-ergonomis. Postur duduk ergonomis ditandai dengan posisi punggung yang tegak mengikuti lengkung alami tulang belakang berbentuk huruf S, sehingga distribusi beban pada tulang belakang terjaga secara merata dan risiko nyeri muskuloskeletal dapat diminimalkan. Sebaliknya, postur duduk non-ergonomis ditandai dengan punggung

membungkuk ke depan (*forward lean*) atau bersandar berlebihan ke belakang (*backward lean*) yang membentuk posisi C, sehingga memberikan tekanan berlebih pada vertebra lumbal dan struktur otot sekitarnya [1]. Kebiasaan duduk dalam postur non-ergonomis dalam jangka waktu yang panjang secara konsisten dikaitkan dengan keluhan nyeri punggung bawah kategori sedang hingga berat, sebagaimana dibuktikan pada penelitian terhadap pengrajin karawo yang menunjukkan bahwa seluruh responden dengan posisi duduk tidak ergonomis mengalami nyeri punggung bawah kategori sedang hingga berat, sementara mereka yang duduk secara ergonomis hanya mengalami nyeri ringan [4].

2.2. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah arsitektur *deep learning* yang dirancang khusus untuk memproses data berbentuk grid seperti citra digital. CNN mengekstraksi fitur dari citra secara hierarkis melalui tiga jenis lapisan utama, yaitu lapisan konvolusi (*convolutional layer*) yang mendeteksi pola lokal seperti tepi dan tekstur menggunakan filter yang dapat dipelajari, lapisan *pooling* yang mereduksi dimensi spasial sambil mempertahankan fitur dominan, serta lapisan *fully connected* yang melakukan klasifikasi berdasarkan fitur yang telah diekstraksi [13]. Keunggulan CNN dibandingkan metode konvensional terletak pada kemampuannya mempelajari representasi fitur secara otomatis langsung dari data gambar mentah tanpa memerlukan rekayasa fitur secara manual. Hal ini dibuktikan oleh [13] yang menunjukkan bahwa CNN mampu mencapai *top-5 error rate* sebesar 15,3% pada kompetisi *ImageNet Large Scale Visual Recognition Challenge (ILSVRC)* 2012, jauh melampaui metode terbaik sebelumnya yang mencapai 26,2%.

2.3. MobileNetV2

MobileNetV2 adalah arsitektur CNN yang dikembangkan oleh Google dan dirancang untuk efisiensi komputasi pada perangkat dengan sumber daya terbatas [14]. Arsitektur ini memperkenalkan dua inovasi utama yaitu *inverted residual block* dan *linear bottleneck*. Pada *inverted residual block*, fitur diproyeksikan ke dimensi yang lebih tinggi terlebih dahulu sebelum dikenai konvolusi

depthwise, kemudian diproyeksikan kembali ke dimensi lebih rendah, yang berlawanan dengan desain residual konvensional. Sementara itu, *linear bottleneck* menghilangkan fungsi aktivasi non-linear pada layer proyeksi akhir untuk mencegah hilangnya informasi pada ruang fitur berukuran kecil. [14] menunjukkan bahwa MobileNetV2 hanya membutuhkan 300 juta *multiply-add operations* dan 3,4 juta parameter untuk mencapai akurasi *top-1* sebesar 72% pada dataset ImageNet, menjadikannya sangat efisien untuk digunakan sebagai *feature extractor* dalam pendekatan *transfer learning*.

2.4. Transfer Learning dan Fine-Tuning

Transfer learning adalah teknik dalam *deep learning* di mana model yang telah dilatih pada dataset besar dialihfungsikan untuk menyelesaikan tugas baru yang berkaitan. Dalam pendekatan ini, bobot (*weights*) yang telah dipelajari dari dataset skala besar seperti *ImageNet* dimanfaatkan sebagai titik awal pelatihan, sehingga model tidak perlu dilatih dari awal (*from scratch*). [15] secara konsisten menunjukkan bahwa CNN prelatih dengan *fine-tuning* yang memadai mampu mengungguli atau setara dengan CNN yang dilatih dari awal, bahkan ketika data pelatihan yang tersedia sangat terbatas. Strategi yang umum digunakan adalah membekukan (*freeze*) seluruh bobot *backbone* CNN prelatih kemudian melatih *classification head* baru di atasnya pada fase pertama, dilanjutkan dengan *fine-tuning* sebagian layer *backbone* teratas menggunakan *learning rate* yang sangat kecil pada fase kedua agar fitur tingkat tinggi dapat disesuaikan dengan karakteristik domain data target [15].

2.5. Augmentasi Data

Augmentasi data adalah teknik untuk memperluas ukuran dan keragaman dataset pelatihan secara artifisial dengan menerapkan transformasi pada citra asli tanpa mengubah label kelasnya. Transformasi yang umum diterapkan meliputi rotasi, pergeseran horizontal dan vertikal, *zoom*, *flip* horizontal, serta penyesuaian kecerahan. [16] menyebutkan bahwa augmentasi data berperan penting dalam mengurangi *overfitting* dan meningkatkan kemampuan generalisasi model dengan memperluas distribusi data pelatihan sehingga lebih merepresentasikan variasi yang mungkin


ditemui pada data uji, khususnya ketika jumlah data pelatihan yang tersedia relatif terbatas. Pada penelitian ini, augmentasi diterapkan hanya pada data latih, sedangkan data validasi dan pengujian hanya menjalani normalisasi piksel untuk memastikan evaluasi dilakukan pada kondisi data yang tidak dimodifikasi.

2.6. Evaluasi Model Klasifikasi

Kinerja model klasifikasi dievaluasi menggunakan beberapa metrik yang saling melengkapi. *Accuracy* mengukur proporsi prediksi yang benar dari seluruh data uji. *Precision* per kelas mengukur seberapa tepat prediksi positif model untuk kelas tersebut, sedangkan *recall* mengukur kemampuan model mendeteksi semua sampel yang benar-benar termasuk kelas tersebut. *F1-score* merupakan rata-rata harmonik dari *precision* dan *recall* yang memberikan gambaran seimbang terutama pada kondisi distribusi kelas yang tidak seimbang. [17] menjelaskan bahwa *precision* dan *recall* merupakan ukuran yang bersifat bias karena dipengaruhi oleh *prevalence* dan *label bias* dari data, sehingga penggunaan keduanya perlu disertai pemahaman atas keterbatasan tersebut. *Confusion matrix* melengkapi metrik-metrik di atas dengan menyajikan distribusi prediksi benar dan salah secara lengkap untuk setiap kombinasi kelas aktual dan kelas prediksi, sehingga pola kesalahan klasifikasi antarkelas dapat diidentifikasi secara spesifik.

3. METODE PENELITIAN

Penelitian ini menggunakan metode eksperimen komputasional dengan pendekatan *deep learning* berbasis *transfer learning* untuk membangun sistem klasifikasi postur duduk manusia secara otomatis. Secara keseluruhan, alur penelitian terdiri dari lima tahap utama yaitu pengumpulan data, persiapan data, perancangan model, pelatihan model, dan evaluasi model. Arsitektur yang digunakan adalah MobileNetV2 dengan strategi *progressive fine-tuning* yang dilatih menggunakan dataset citra postur duduk dari platform Roboflow Universe. Performa model dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* pada data uji yang sepenuhnya independen dari data latih.



Gambar 1. Tahapan Penelitian

3.1. Pengumpulan Data

Pada penelitian ini, data yang digunakan diperoleh dari platform Roboflow Universe yang menyediakan dataset citra postur duduk manusia yang telah dilabeli secara manual. Dataset yang digunakan berjudul "*Sitting Posture*" yang dapat diakses secara publik melalui tautan

<https://universe.roboflow.com/dataset-sqm0h/sitting-posture-ezkda>.

Dataset ini dipilih karena relevansinya dengan topik penelitian serta ketersediaan anotasi kelas yang jelas dan terstruktur. Dataset terdiri dari tiga kelas postur duduk, yaitu *good posture* (postur duduk tegak yang baik), *forward lean_bad posture* (postur membungkuk ke depan), dan *backward lean_bad posture* (postur bersandar ke belakang secara berlebihan). Ketiga kelas tersebut merepresentasikan kondisi postur duduk yang umum dijumpai dalam aktivitas sehari-hari, khususnya saat bekerja atau belajar menggunakan komputer.

Data citra yang dikumpulkan telah dibagi menjadi tiga subset oleh penyedia dataset, yaitu data latih (*training set*), data validasi (*validation set*), dan data uji (*test set*). Pembagian ini dilakukan untuk memastikan proses pelatihan model berlangsung secara objektif dan hasil evaluasi model dapat mencerminkan kemampuan generalisasi terhadap data yang belum pernah dilihat sebelumnya.

3.2. Persiapan Data

Persiapan data mencakup dua tahap utama yaitu pra-pemrosesan dan augmentasi. Pada tahap pra-pemrosesan, dataset yang diunduh dari Roboflow Universe memiliki struktur direktori datar (*flat directory*) sehingga perlu dilakukan reorganisasi agar kompatibel dengan ImageDataGenerator pada Keras yang mensyaratkan setiap kelas memiliki subfolder tersendiri. Reorganisasi dilakukan secara

otomatis menggunakan skrip Python yang mendeteksi kelas berdasarkan awalan nama file (*filename prefix*) kemudian menyalin citra ke subfolder yang sesuai. Seluruh citra kemudian diseragamkan ukurannya menjadi 224×224 piksel sesuai dimensi masukan MobileNetV2, lalu dinormalisasi dengan membagi nilai piksel dengan 255 sehingga berada pada rentang 0 hingga 1 guna mempercepat konvergensi model.

Augmentasi data diterapkan secara *on-the-fly* menggunakan ImageDataGenerator khusus pada data latih, sementara data validasi dan data uji hanya menjalani normalisasi tanpa transformasi tambahan agar evaluasi mencerminkan performa model pada kondisi nyata. Transformasi yang diterapkan meliputi rotasi hingga 15 derajat, pergeseran horizontal dan vertikal masing-masing 10%, pembesaran (*zoom*) hingga 15%, pembalikan horizontal (*horizontal flip*), serta penyesuaian kecerahan pada rentang 0,8 hingga 1,2. Karena augmentasi bersifat *on-the-fly*, setiap epoch menghasilkan variasi citra yang berbeda-beda sehingga model terpapar sampel yang beragam sepanjang proses pelatihan tanpa perlu menambah jumlah file citra di penyimpanan.

3.3. Perancangan Model

Model dirancang menggunakan pendekatan *transfer learning* berbasis arsitektur MobileNetV2 yang telah dilatih pada dataset ImageNet. MobileNetV2 dipilih karena arsitekturnya yang ringan dan efisien dengan memanfaatkan *depthwise separable convolution* serta mekanisme *inverted residuals* dan *linear bottleneck*, sehingga mampu menghasilkan ekstraksi fitur yang kuat dengan jumlah parameter yang jauh lebih kecil dibandingkan arsitektur CNN konvensional. Di atas *backbone* MobileNetV2 yang dibekukan (*frozen*), ditambahkan *classification head* yang terdiri dari lapisan *Global Average Pooling* untuk meratakan peta fitur, lapisan *Dense 256* neuron dengan aktivasi ReLU, *Batch Normalization* untuk menstabilkan distribusi aktivasi antarlayer, *Dropout* dengan laju 0,3 untuk mencegah overfitting, serta lapisan keluaran *Dense 3* neuron dengan aktivasi *softmax* yang menghasilkan probabilitas prediksi untuk kelas *good_posture*, *forward_lean*, dan *backward_lean*. Fungsi loss yang digunakan adalah *categorical*

crossentropy dengan optimizer Adam dan metrik pemantauan *accuracy*.

3.4. Pelatihan Model

Pelatihan dilakukan dalam dua fase menggunakan strategi *progressive fine-tuning*. Pada fase pertama, seluruh lapisan *backbone* MobileNetV2 dibekukan dan hanya *classification head* yang dilatih menggunakan optimizer Adam dengan laju pembelajaran 1×10^{-3} selama maksimal 20 *epoch*. Fase ini bertujuan membentuk bobot *classification head* yang optimal sebelum *backbone* ikut disesuaikan. Pada fase kedua, 100 lapisan pertama *backbone* tetap dibekukan sementara lapisan-lapisan setelahnya dibuka untuk dilatih bersama *classification head* menggunakan laju pembelajaran yang jauh lebih kecil yaitu 1×10^{-5} selama maksimal 30 *epoch*, guna mencegah perubahan bobot *backbone* yang terlalu drastis. Pada kedua fase diterapkan tiga *callback*, yaitu *ModelCheckpoint* untuk menyimpan bobot terbaik berdasarkan *val_accuracy*, *EarlyStopping* dengan *patience 7 epoch* untuk menghentikan pelatihan apabila *val_accuracy* tidak menunjukkan peningkatan, serta *ReduceLROnPlateau* yang secara otomatis menurunkan laju pembelajaran sebesar faktor 0,3 apabila *val_loss* tidak mengalami penurunan selama 4 *epoch* berturut-turut.

3.5. Evaluasi Model

Evaluasi dilakukan menggunakan data uji yang sepenuhnya terpisah dari data latih dan validasi untuk mengukur kemampuan generalisasi model secara objektif. Metrik yang digunakan meliputi *accuracy* sebagai ukuran keseluruhan, serta *precision*, *recall*, dan *F1-score* per kelas dari *classification report* untuk menilai performa model secara lebih granular pada masing-masing kelas postur duduk. Hasil evaluasi juga divisualisasikan menggunakan *confusion matrix* dalam dua bentuk, yaitu jumlah absolut dan ternormalisasi, untuk mengidentifikasi pola kesalahan klasifikasi antar kelas secara rinci. Model akhir disimpan dalam format Keras (*.keras*) dan dikonversi ke format TFLite untuk memungkinkan penerapan pada perangkat mobile dengan sumber daya komputasi terbatas.

4. HASIL DAN PEMBAHASAN

4.1. Dataset


Dataset yang digunakan terdiri dari 938 citra yang terbagi menjadi tiga subset, yaitu data latih sebanyak 657 citra, data validasi 187 citra, dan data uji 94 citra. Distribusi per kelas pada data latih adalah *good_posture* 327 citra, *backward_lean* 167 citra, dan *forward_lean* 163 citra, dengan distribusi serupa pada subset validasi dan uji. Terdapat ketidakseimbangan kelas (*class imbalance*) ringan di mana *good_posture* mendominasi sekitar 50% dari total data, namun hal ini diatasi melalui augmentasi *on-the-fly* yang menghasilkan estimasi 32.850 sampel efektif selama 50 epoch pelatihan. Gambar 2 menunjukkan sampel citra dari ketiga kelas sebelum dan sesudah augmentasi diterapkan.



Gambar 2. Sampel Gambar

4.2. Pelatihan Model

Gambar 3 menunjukkan kurva training history pada fase 1 dan fase 2. Pada fase 1 dengan backbone dibekukan, model mencapai konvergensi yang cepat di mana akurasi validasi mencapai 87,70% sejak epoch pertama dan terus meningkat hingga mencapai nilai terbaik 97,33% pada epoch ke-9. EarlyStopping menghentikan pelatihan pada epoch ke-16 karena tidak ada peningkatan signifikan dalam 7 epoch terakhir. Mekanisme ReduceLROnPlateau juga aktif dua kali, menurunkan laju pembelajaran dari 1×10^{-3} menjadi 3×10^{-4} lalu 9×10^{-5} , yang menunjukkan bahwa model telah mendekati titik optimal pada ruang parameter classification head. Pada fase 2 dengan fine-tuning parsial, nilai *val_accuracy* terbaik tetap berada di 97,33% dan EarlyStopping menghentikan pelatihan lebih awal pada epoch ke-8 dari maksimal 30 epoch, mengindikasikan bahwa bobot backbone yang diperoleh dari fase 1 sudah cukup optimal sehingga penyesuaian lebih lanjut tidak memberikan peningkatan yang berarti.



Gambar 3. Training History

4.3. Evaluasi Model

Model dievaluasi pada 94 data uji yang independen dan menghasilkan akurasi sebesar 95,74% dengan *test loss* 0,1391. Tabel 1 merangkum hasil *classification report* per kelas.

Tabel 1. Classification Report pada Data Uji


Kelas	Precision	Recall	F1-Score	Support
backward lean	0,9583	0,9583	0,9583	24
forward lean	0,9643	0,9310	0,9474	29
good posture	0,9524	0,9756	0,9639	41
Macro avg	0,9583	0,9550	0,9565	94
Weighted avg	0,9576	0,9574	0,9574	94

Kelas *good_posture* memperoleh *recall* tertinggi sebesar 97,56%, artinya model sangat jarang salah mengklasifikasikan postur duduk baik sebagai postur buruk. Kelas *forward_lean* memiliki *recall* terendah 93,10% yang mengindikasikan adanya sedikit kesulitan dalam membedakan posisi membungkuk ke depan dari kelas lain. Rata-rata *confidence* model pada prediksi yang benar mencapai 97,8%, sementara pada prediksi yang salah hanya 76,4%, menunjukkan model mampu membedakan antara prediksi yang yakin dan prediksi yang ragu secara konsisten.

4.4. Analisis Confusion matrix

Gambar 4 menampilkan *confusion matrix* dalam bentuk jumlah absolut dan ternormalisasi. Dari 94 sampel uji, hanya 4 sampel yang salah diklasifikasikan 1 sampel *backward_lean* diprediksi sebagai *good_posture*, 1 sampel *forward_lean* diprediksi sebagai *backward_lean*, 1 sampel *forward_lean* diprediksi sebagai *good_posture*, dan 1 sampel *good_posture* diprediksi sebagai *forward_lean*. Pola kesalahan ini wajar mengingat postur *forward_lean* dan *backward_lean* pada sudut kamera tertentu dapat memiliki bentuk tubuh yang secara visual mirip satu sama lain. Tidak ditemukan kesalahan klasifikasi antara *backward_lean* dan

forward_lean secara langsung dalam jumlah besar, yang menunjukkan bahwa model berhasil mempelajari fitur diskriminatif yang cukup kuat untuk memisahkan kedua kelas postur buruk tersebut.



Gambar 4. Confusion Matrix

4.5. Pembahasan

Hasil yang diperoleh menunjukkan bahwa pendekatan *transfer learning* berbasis MobileNetV2 sangat efektif untuk klasifikasi postur duduk meskipun jumlah data relatif terbatas (938 citra). Akurasi 95,74% pada data uji dengan *macro F1-score* 0,9565 mengindikasikan performa yang seimbang di seluruh kelas tanpa bias yang signifikan terhadap kelas mayoritas. Fakta bahwa fase 2 tidak memberikan peningkatan *val_accuracy* di atas fase 1 menunjukkan bahwa fitur yang dipelajari MobileNetV2 dari ImageNet sudah sangat transferable untuk domain postur tubuh manusia, sehingga *fine-tuning* lebih lanjut tidak diperlukan secara signifikan. Model akhir yang dikonversi ke format TFLite berukuran ringan dan siap diimplementasikan pada perangkat mobile untuk pemantauan postur duduk secara *real-time*.

5. KESIMPULAN

- Model klasifikasi postur duduk berbasis *transfer learning* MobileNetV2 berhasil dibangun dan mencapai akurasi 95,74% pada data uji dengan *macro F1-score* 0,9565, menunjukkan bahwa pendekatan ini efektif untuk mendeteksi tiga kelas postur duduk (*good_posture*, *forward_lean*, dan *backward_lean*) secara otomatis dari data citra.
- Strategi progressive fine-tuning dua fase terbukti efisien, di mana performa terbaik sudah tercapai pada fase 1 (*val_accuracy* 97,33%) dan fase 2 tidak memberikan peningkatan signifikan, mengindikasikan bahwa fitur yang dipelajari MobileNetV2 dari ImageNet sudah sangat transferable untuk domain postur tubuh manusia

meskipun dengan data yang relatif terbatas (938 citra).

- Kelebihan model yang dihasilkan meliputi arsitektur yang ringan (9,87 MB), kompatibel dengan format TFLite untuk deployment pada perangkat mobile, serta mampu membedakan postur duduk dengan rata-rata *confidence* 97,8% pada prediksi yang benar.
- Kekurangan penelitian ini terletak pada jumlah data yang masih terbatas dan distribusi kelas yang tidak seimbang (*good_posture* mendominasi ~50% data), serta dataset yang hanya mencakup sudut pengambilan gambar dari sisi samping sehingga kemampuan generalisasi model pada sudut kamera yang berbeda belum teruji.
- Pengembangan selanjutnya dapat difokuskan pada perluasan dataset dengan variasi sudut kamera, penambahan kelas postur duduk yang lebih beragam, serta implementasi model secara *real-time* menggunakan kamera pada perangkat mobile atau sistem pemantauan berbasis *edge computing* untuk aplikasi kesehatan kerja dan ergonomis.

UCAPAN TERIMA KASIH

Saya mengucapkan terima kasih kepada Universitas dan Program Studi yang telah memberikan fasilitas dan dukungan akademik dalam pelaksanaan penelitian ini. Penulis juga mengucapkan terima kasih kepada Roboflow Universe yang telah menyediakan dataset postur duduk secara publik sehingga penelitian ini dapat terlaksana. Tidak lupa penulis mengucapkan terima kasih kepada seluruh pihak yang telah memberikan masukan, saran, dan dukungan selama proses penelitian dan penulisan artikel ini berlangsung.

DAFTAR PUSTAKA

- S. W. Lerita, C. Roosarjani, and H. Laili, "Korelasi Sikap Duduk dan Durasi Duduk dengan Masalah Muskuloskeletal Pada Mahasiswa TBD Angkatan 7," vol. 2, no. November 2024, pp. 1–10, 2025.
- W. H. Organization, "Musculoskeletal health," World Health Organization. Accessed: May 01, 2026. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/musculoskeletal-conditions>
- C. Tahun, D. Arihta, E. E. Sabaruddin, and R.

- Martya, “Keluhan Musculoskeletal Disorders (MSDs) Dengan Postur Kerja, Indeks Massa Tubuh (IMT) Dan Masa Kerja Pada Pekerja Packing Di Unit Tower PT. Bukaka Teknik Utama Tbk. Cileungsi Tahun 2023.,” vol. 13, no. 1, pp. 79–94, 2024.
- [4] A. N. Sudirman, N. U. I. Biahimo, M. Puspita, and S. Kai, “Hubungan Posisi Duduk Ergonomis Dengan Nyeri Punggung Bawah Pada Pengrajin Karawo,” pp. 1–11.
- [5] N. S. Nadhifa, D. Syauqy, and E. R. Widasari, “Pengembangan Sistem Wearable untuk Deteksi Postur Duduk Miring Berbasis Data Sensor MPU6050 dan Metode Support Vector Machine,” vol. 9, no. 3, pp. 1–10, 2025.
- [6] L. Alfarizy, D. Syauqy, and R. S. Perdana, “Sistem Monitoring Postur Duduk pada Pemain Game Online menggunakan Sensor Load Cell dan Ultrasonik dengan Metode K-Nearest Neighbor (KNN) berbasis Arduino,” vol. 7, no. 4, 2023.
- [7] A. A. Elngar, M. Arafa, A. Fathy, and B. Moustafa, “Image Classification Based On CNN: A Survey,” vol. 6, no. 1, pp. 18–50, 2021, doi: 10.5281/zenodo.4897990.
- [8] M. A. Hossain and M. S. A. Sajib, “Classification of Image using Convolutional Neural Network (CNN),” vol. 19, no. 2, 2019.
- [9] A. Taner and B. Öztekin, “Performance Analysis of Deep Learning CNN Models for Variety Classification in Hazelnut,” 2021.
- [10] T. R. Nugrahanto, I. Badruddin, and M. D. Amrulloh, “Perbandingan Random Forest , K-Nearest Neighbor , Support Vector Machine , dan Multi-Layer Perceptron untuk Deteksi Postur Duduk Berdasarkan Ekstraksi Pose MediaPipe,” no. November, pp. 26–37, 2025.
- [11] G. Vista, Y. Candra, D. P. Pamungkas, and P. Kasih, “Analisis Performa Metode CNN Dan LSTM Untuk Deteksi Gerakan Angkat Beban,” vol. 9, pp. 171–180, 2025.
- [12] M. R. Wedatama, L. J. E. Dewi, and N. W. Marti, “Klasifikasi Pose Yoga Surya Namaskar Menggunakan Algoritma Convolutional Neural Network Dengan Arsitektur VGG19,” vol. 14, no. 1, pp. 862–868.
- [13] A. Krizhevsky and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” pp. 1–9.
- [14] M. Sandler, A. Howard, M. Zhu, and A. Zhmoginov, “MobileNetV2: Inverted Residuals and Linear Bottlenecks,” pp. 4510–4520.
- [15] N. Tajbakhsh *et al.*, “Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?,” vol. 35, no. 5, pp. 1299–1312, 2016.
- [16] C. Shorten and T. M. Khoshgoftaar, “A survey on Image Data Augmentation for Deep Learning,” *J. Big Data*, 2019, doi: 10.1186/s40537-019-0197-0.
- [17] D. M. W. Powers, “Evaluation: From Precision , Recall and F-Factor to ROC , Informedness , Markedness & Correlation,” no. December, 2007.